

# PATENT ABSTRACTS OF JAPAN

(11)Publication number : 06-286630

(43)Date of publication of application : 11.10.1994

(51)Int.Cl.

B62D 6/00  
// B62D101:00  
B62D103:00  
B62D105:00  
B62D109:00  
B62D113:00  
B62D123:00  
B62D127:00  
B62D137:00

(21)Application number : 05-074182

(71)Applicant : NISSAN MOTOR CO LTD

(22)Date of filing : 31.03.1993


(72)Inventor : CHINMOI PARU  
INOUE HIDEAKI

## (54) ROAD SURFACE FRICTIONAL COEFFICIENT ESTIMATING DEVICE

### (57)Abstract:

**PURPOSE:** To estimate the road surface frictional coefficient which can not be measured directly, with high precision, by detecting the vehicle traveling state and inputting the state to a neural network, as for a road surface frictional coefficient estimating device during the traveling of a vehicle.

**CONSTITUTION:** Into a controller 2, each information representing the traveling state is supplied from a steering angle sensor 21, car speed sensor 22, yaw rate sensor 23, lateral slip angle sensor 24, and a rear wheel steering angle sensor 25. The controller reads these information in each prescribed interruption timing by using a microcomputer and executes the calculation processing based on the neural network, and calculates the road surface frictional efficient. The neural network allows plural numerical values to be outputted in parallel, and consists of the equal number of elements to a plurality of outputs, and learning is carried out, having the numerical series set in the pattern corresponding to the well-know road surface frictional coefficient, as learning signal, and calculation processing is carried out.



### LEGAL STATUS

[Date of request for examination]

14.09.1998

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than  
the examiner's decision of rejection or  
application converted registration]

[Date of final disposal for application]

[Patent number] 3067453

[Date of registration] 19.05.2000

[Number of appeal against examiner's decision of  
rejection]

[Date of requesting appeal against examiner's  
decision of rejection]

[Date of extinction of right]

Copyright (C); 1998,2003 Japan Patent Office

(19)日本国特許庁 (J P)

(12) 公 開 特 許 公 報 (A)

(11)特許出願公開番号

特開平6-286630

(43)公開日 平成 6 年(1994)10月11日

(51)Int.Cl.<sup>5</sup>

B 6 2 D 6/00

// B 6 2 D 101:00

103:00

105:00

109:00

識別記号

庁内整理番号

9034-3D

F I

技術表示箇所

審査請求 未請求 請求項の数 3 O L (全 13 頁) 最終頁に続く

(21)出願番号

特願平5-74182

(22)出願日

平成 5 年(1993) 3 月31日

(71)出願人 000003997

日産自動車株式会社

神奈川県横浜市神奈川区宝町 2 番地

(72)発明者 チンモイ バル

神奈川県横浜市神奈川区宝町 2 番地 日産  
自動車株式会社内

(72)発明者 井上 秀明

神奈川県横浜市神奈川区宝町 2 番地 日産  
自動車株式会社内


(74)代理人 弁理士 森 哲也 (外 2 名)

(54)【発明の名称】 路面摩擦係数推定装置

(57)【要約】

【目的】車両走行中に直接測定が困難な走行路面の摩擦係数を演算できるようにする。

【構成】路面摩擦係数の影響を受けるセンサ出力である操舵角  $\theta$ 、車速  $v$ 、ヨーレート  $\phi$ 、横滑り角  $\beta$  等を入力とし、路面摩擦係数  $\mu$  を出力とするニューラルネットワーク NN によって、路面摩擦係数  $\mu$  を推定する構成とする。



## 【特許請求の範囲】

【請求項 1】 車両の走行状態を検出する車両走行状態検出手段と、この車両走行状態検出手段が検出した車両の走行状態を入力とし路面摩擦係数を出力とするニューラルネットワークと、を備えたことを特徴とする路面摩擦係数推定装置。

【請求項 2】 前記ニューラルネットワークは、複数個の数値を並列に出力するニューラルネットワークを用いるとともに、前記複数個の出力と同じ個数の要素からなり既知の路面摩擦係数に応じたパターンに設定される数

列を教師信号として学習を行ったものである請求項 1 記載の路面摩擦係数推定装置。

## 【発明の詳細な説明】

## 【0001】

【産業上の利用分野】 この発明は、車両走行中にその走行路面の摩擦係数を推定する装置に関し、特に、ニューラルネットワークを利用することにより、比較的検出の容易な車両の走行状態に関する情報に基づいて、走行中に直接測定することが困難な路面摩擦係数を推定可能としたものである。

## 【0002】

【従来の技術】 従来から 4WS（4 輪操舵装置）、ABS（アンチロック・ブレーキ・システム）、TCS（トラクション・コントロール・システム）、4WD（4 輪駆動装置）等のように車両の操縦安定性を高める種々の技術が存在しており、これらは実際に車両に搭載されて操縦安定性の向上に大きく貢献している。

【0003】 しかし、上記のような操縦安定性を高める従来の装置にあっては、走行路面の摩擦係数自体を測定又は推定しその結果を考慮して制御を行っているものは存在しなかった。これは、路面の摩擦係数は、車両走行中に直接測定することが非常に困難だからである。従って、走行路面の摩擦係数は一定の値であると仮定して制御を行うことになるのであるが、当然に実際の走行路面の摩擦係数は一定の値ではない。このため、摩擦係数がどのような値であっても車両の操縦安定性を損なわないように 4WS における後輪舵角制御や 4WD における駆動力配分制御を行わなければならないのであり、摩擦係数を考慮できない分、それら操縦安定性を高める技術の有する能力が十分に活用されていないのが現状である。

【0004】 なお、路面の滑り状態を前後輪の車輪速差や雨滴センサ等から間接的に判断して制御内容を変更する程度のものは存在するが（例えば、特開平 1-95968 号公報等参照）、車輪速差や雨滴センサ等から判断するため、路面の滑り状態の検出精度はそれほど高くな

い。また、超音波センサ等を使って路面の荒さを読み取る技術も研究されているが、実用レベルには至っていない。

【0005】 一方、車両パラメータのうち測定が容易なパラメータに基づいて、測定が困難なパラメータを推定するという技術が存在し（特開平 4-138970 号公報参照）、かかる従来の技術では、推定演算のためにニューラルネットワークを利用していた。即ち、上記公開公報に開示された従来の技術は、車両パラメータを、他の車両パラメータに基づいてニューラルネットワークを利用して推定するというものであり、具体的に開示されているのは、車両に発生している前後加速度、横加速度、上下加速度、操舵トルク、前輪舵角、車速、後輪舵角等に基づいて、その車両に発生しているであろう横滑り角及びヨーレートを推定する技術であり、いずれにしても、車両パラメータに基づいて他の車両パラメータを推定する技術のみが開示されている。

## 【0006】

【発明が解決しようとする課題】 しかしながら、横滑り角及びヨーレートは現在では安価なジャイロ等を用いることにより容易に直接測定できるパラメータであり、これを推定するためにニューラルネットワークを利用する必要性は薄れている。つまり、車両の挙動そのものである車両パラメータを推定するためにニューラルネットワークを用いる必要性は現在では皆無といってもいいのであり、むしろ、そのような検出が容易な車両の挙動に基づいて、車両の操縦安定性に大きく影響を与えるが直接測定が困難な数値等をニューラルネットワークによって推定するのが望ましいのである。

【0007】 本発明は、このような観点からなされたものであり、車両の操縦安定性に大きな影響を与える路面の摩擦係数を、実際に測定が容易な情報に基づいて推定する装置を提供することを目的としている。

## 【0008】

【課題を解決するための手段】 上記目的を達成するために、請求項 1 記載の発明である路面摩擦係数推定装置は、車両の走行状態を検出する車両走行状態検出手段と、この車両走行状態検出手段が検出した車両の走行状態を入力とし路面摩擦係数を出力とするニューラルネットワークと、を備えた。

【0009】 また、請求項 2 記載の発明である路面摩擦係数推定装置は、上記請求項 1 記載の発明において、前記ニューラルネットワークは、複数個の数値を並列に出力するニューラルネットワークを用いるとともに、前記複数個の出力と同じ個数の要素からなり既知の路面摩擦係数に応じたパターンに設定される数列を教師信号として学習を行ったものである。

【0010】 さらに、請求項 3 記載の発明である路面摩擦係数推定装置は、上記請求項 1 又は請求項 2 記載の発明において、前記ニューラルネットワークは、自己回帰

モデルを有するニューラルネットワークを用いるとともに、前記自己回帰モデルの出力を利用して前記ニューラルネットワークを学習させるオンライン学習手段を設けた。

#### 【0011】

【作用】請求項1記載の発明にあっては、車両走行状態検出手段が車両の走行状態（例えば、舵角、スロットル開度等の運転状態や、前後加速度、ヨーレート等の車両挙動状態等）を検出すると、それらがニューラルネットワークに入力される。すると、ニューラルネットワーク

において各ニューロンの結合状態や入力に対する重み係数等に応じた演算が行われ、ニューラルネットワークの出力層から路面摩擦係数の推定結果が出力される。

【0012】入力として用いられる車両の走行状態は、路面摩擦係数の影響を受けて変化するものである必要があるが、検出可能な車両の走行状態の多くは路面摩擦係数の影響を受けることから、この路面摩擦係数推定装置を搭載する車両における他の制御（例えば、後輪操舵制御、駆動力配分制御等）で使用されているセンサの出力を利用すればよい。また、ニューラルネットワークは、車両に搭載される前に、そのような車両の走行状態を入力とし既知の路面摩擦係数を教師信号として多くのケースに基づく学習を済ませておく必要がある。

【0013】請求項2記載の発明にあっては、ニューラルネットワークは複数個（ここでは、 $n$ 個とする）の数値を並列に出力するため、それら出力のそれぞれの値を $O_i$ （ $i=1, \dots, n$ ）、ニューラルネットワークの学習の際に用いられる教師信号を $T_j$ （ $j=1, \dots, n$ ）、その教師信号 $T_j$ の各要素を $t_{ji}$ 、教師信号 $T_j$ に対応する既知の路面摩擦係数を $\mu_j^*$ とすれば、出力 $O_i$ が教師信号 $T_j$ の対応する要素 $t_{ji}$ に一致するように例えばバックプロパゲーション等のアルゴリズムに従って学習を行うことによりニューラルネットワークのシステム同定が行われることになる。

【0014】そして、ニューラルネットワークによって路面摩擦係数を推定する際には、複数の出力 $O_i$ によって一つの路面摩擦係数が表されることになるから、一つの出力で路面摩擦係数を表す場合に比べて高精度の推定が行われる。さらに、請求項3記載の発明にあっては、自己回帰モデルを有するニューラルネットワークを用いるとともに、オンライン学習手段を有するため、過渡応答時であっても高精度の路面摩擦係数の推定が行われる。

#### 【0015】

【実施例】以下、この発明の実施例を図面に基づいて説明する。図1は本発明の第1実施例における車両の概略構成図であって、この実施例は、4WS機能を有する車両に本発明に係る路面摩擦係数推定装置を適用したものである。

【0016】先ず、構成を説明すると、図1において、

前輪1L、1Rはナックル（図示せず）を介してタイロッド3L、3Rの外端に連結され、そのタイロッド3L、3Rの内端は、ラックアンドピニオン式ステアリング装置4のラック軸4aに接続されている。そして、ラックアンドピニオン式ステアリング装置4のピニオン軸（図示せず）とステアリングホイール6とがステアリングシャフト5を介して回転伝達可能に接続されている。つまり、前輪1L、1Rは、操縦者がステアリングホイール6を操舵することにより、左右に転舵されるようになっている。

【0017】一方、後輪2L、2Rには、図示しないディファレンシャルギヤボックスで分配された駆動力を受けて回転する車軸10L、10Rの外端が回転力伝達可能に連結されている。従って、この車両は後輪2L、2Rが駆動輪となる後輪駆動車である。さらに、この車両は、モータ11の回転力によって駆動する後輪操舵装置12を有しており、この後輪操舵装置12に内端が連結された後輪操舵用のタイロッド13L、13Rの外端が、後輪2L、2Rに連結されている。従って、後輪2L、2Rは、モータ11に供給する電流を制御することにより、任意の方向に且つ任意の大ききで転舵されるようになっている。

【0018】モータ11には、モータドライバ15が接続されていて、このモータドライバ15と、これに電力を供給するバッテリー16のリレースイッチ16aとが、マイクロコンピュータや必要なインタフェース回路等を含んで構成されるコントローラ20によって制御されるようになっている。コントローラ20は、後述する演算処理を実行して車両の操縦安定性が向上するような目標後輪舵角 $\delta_r^*$ を算出し、そして、後輪2L、2Rの実際の舵角である実後輪舵角 $\delta_r$ がその目標後輪舵角 $\delta_r^*$ に一致するように、モータドライバ15に制御信号CSを出力してモータ11を駆動させるものであり、かかるコントローラ20には、そのような制御に必要な種々の信号が供給されている。

【0019】この実施例では、コントローラ20には、例えば公知のポテンシオメータから構成されステアリングホイール6の操舵角を検出する操舵角センサ21、例えば変速機の出力軸に取り付けられた回転速度計から構成され車速を検出する車速センサ22、例えば公知のジャイロから構成され車両に発生しているヨーレートを検出するヨーレートセンサ23、例えば公知のジャイロ等を利用して構成され車両の横滑り角を検出する横滑り角センサ24及び例えば後輪操舵装置12のギアの回転角等に基づいて後輪2L、2Rの実後輪舵角 $\delta_r$ を検出する後輪舵角センサ25が接続されていて、それら各センサ21～25から供給される操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 、横滑り角 $\beta$ 及び実後輪舵角 $\delta_r$ に基づいて所定の制御を実行する。

【0020】図2はコントローラ10内で実行される後

輪操舵制御に関する処理の概要を示すフローチャートであり、この処理は、図示しないオペレーティングシステムにより所定周期（例えば、5 msec）毎の割り込み処理として実行される。処理の流れをフローチャートに従って説明すると、先ずそのステップ101において、操舵角センサ21から供給される操舵角 $\theta$ 、車速センサ22から供給される車速 $v$ 、ヨーレートセンサから供給されるヨーレート $\phi$ 、横滑り角センサ24から供給される横滑り角 $\beta$ 及び後輪舵角センサ25から供給される実後輪舵角 $\delta_r$ を読み込む。

$$C_1 = C_0 \cdot \mu$$

ステップ102で演算される路面摩擦係数 $\mu$ は、 $0.0 \leq \mu \leq 1.0$ という範囲に収まる無次元化された係数であって、乾いた舗装路のように滑り難い状態で1.0に近い値を採り、凍結された路面のように滑り易い状態では0.0に近い値を採るようになっている。従って、後輪舵角決定用係数 $C_1$ は、走行路面が滑り難い状態では定数 $C_0$ に近い値を採り、走行路面が滑り易くなるほど小さい値

$$\phi^* = \{G_0 / (1 + \tau_0 s)\} \delta_r$$

なお、前輪舵角 $\delta_f$ は、前輪1L、1R側のステアリングギア比 $N$ から、

$$\delta_f = \theta / N$$

として求められる。また、

$$G_0 = C_1 V L / (M L_r V^2 + L L_r C_1)$$

$$\tau_0 = V I / (M L_r V^2 + L L_r C_1)$$

$$\delta_r^* = K_p (\phi^* - \phi)$$

$K_p$ は比例定数である。このように目標ヨーレート $\phi^*$ と実際のヨーレート $\phi$ との偏差に比例定数 $K_p$ を乗じることにより目標後輪舵角 $\delta_r^*$ が決定されるのであるから、比例定数 $K_p$ を大きくすれば外乱があっても車両を目標ヨーレート $\phi^*$ に近づけることが可能であるが、実際にはモータ11等の応答遅れ等が存在するため、比例定数 $K_p$ をあまり大きくすることはできない。ここでは、 $K_p = -1$  (sec) とする。

【0025】そして、ステップ106に移行し、実後輪舵角 $\delta_r$ が目標後輪舵角 $\delta_r^*$ に一致するようなモータドライバ15に対する制御信号 $CS$ を決定し、この制御信号 $CS$ をステップ107においてモータドライバ15に供給する。なお、ステップ107では、リレースイッチ16aがオフの場合にはこれをオンとするような制御信号も出力する。モータドライバ15に制御信号を供給したら、今回の割り込み処理を終了し、次の割り込みタイミングとなったらステップ101に戻って上述した処

$$y = \varepsilon + \sum_k x_k w_k$$

ニューラルネットワークNNは、車両に搭載される前に学習を行っておく必要がある。具体的には、多数パターンの操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 及び横滑り角 $\beta$ に対する既知の路面摩擦係数 $\mu^*$ を教師信号として、その既知の路面摩擦係数 $\mu^*$ と出力層のニューロン $n_r$ から

【0021】次いで、ステップ102に移行し、ステップ101で読み込んだ操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 及び横滑り角 $\beta$ を入力として、図3に示すようなニューラルネットワークNNに基づく演算処理を実行して、路面摩擦係数 $\mu$ を演算する。ニューラルネットワークNNの内容については後に詳細に説明する。そして、ステップ103に移行し、次のステップ104で使用する後輪舵角決定用係数 $C_1$ を下記の(1)式に従って設定する。

$$\text{【0022】} \quad \dots\dots (1)$$

を採ることになる。

【0023】ステップ103の演算が行われた後には、ステップ104に移行し、車両を2輪モデルで近似して横滑り角 $\beta = 0$ とした場合のヨーレート $\phi$ と前輪舵角 $\delta_f$ との関係を表す下記の(2)式に従って、目標ヨーレート $\phi^*$ を演算する。

$$\text{【0024】} \quad \dots\dots (2)$$

であり、 $M$ 、 $I$ 、 $L_f$ 、 $L_r$ 、 $L$  ( $= L_f + L_r$ ) は車両諸元等によって決まる定数、 $s$ はラプラス演算子である。

【0024】目標ヨーレート $\phi^*$ が求められたら、ステップ105に移行し、下記の(3)式に従って目標後輪舵角 $\delta_r^*$ を演算する。

$$\text{【0025】} \quad \dots\dots (3)$$

理を繰り返し実行するようになっている。

【0026】ここで、ステップ102における路面摩擦係数 $\mu$ の演算に用いられるニューラルネットワークNNは、図3に示すように、操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 及び横滑り角 $\beta$ を入力とし、路面摩擦係数 $\mu$ を出力としたネットワークであって、この例では、入力層、中間層及び出力層の三層構造のニューラルネットワークNNを用いている。

【0027】そして、ニューラルネットワークNNを構成する各ニューロン $n_r$ は、所定個数の入力 $x_k$ に対して一つの出力 $y$ を生成する処理要素であって、所定の伝達関数に従って出力 $y$ を生成する。例えば、各ニューロン $n_r$ への個々の入力に対する重み係数を $w_k$ 、自己の状態に関する定数を $\varepsilon$ とすれば、下記の(4)式のような伝達関数を用いることができる。

$$\text{【0028】} \quad \dots\dots (4)$$

出力される路面摩擦係数 $\mu$ との誤差が小さくなるように、各ニューロン $n_r$ の重み係数や定数 $\varepsilon$ を更新するのである。このような学習のアルゴリズムとしては、例えば公知のバックプロパゲーション等が適用される。

【0029】図4(b)～(g)は、車速 $v = 100$  km

／hにおいて操舵角 $\theta$ を図4(a)に示すように正弦波状に変化させた場合のヨーレート $\phi$ 及び横滑り角 $\beta$ の変化を複数の路面摩擦係数 $\mu$ (=1.0, 0.4, 0.1)毎に求めた車体運動シミュレーションの結果を示す波形図であり、これら波形図からも判るように、操舵に対する応答としてのヨーレート $\phi$ 及び横滑り角 $\beta$ は、路面摩擦係数 $\mu$ の影響を受けて大きく変化するものである。なお、ここには図示しないが、車速 $v$ が異なればヨーレート $\phi$ 及び横滑り角 $\beta$ の波形も変化することが判っている。

【0030】従って、図3に示すようなニューラルネットワークNNを用いれば、路面摩擦係数 $\mu$ を推定することは十分に可能である。次に、本実施例の動作を説明する。コントローラ20内のマイクロコンピュータにおいて所定の割り込みタイミング毎に図2に示す処理が実行されるため、各センサの出力値である操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 、横滑り角 $\beta$ 及び実後輪舵角 $\delta_r$ が読み込まれ、そして、操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 及

び横滑り角 $\beta$ を入力として、図3に示したニューラルネットワークNNに基づく演算処理が実行され、路面摩擦係数 $\mu$ が演算される。ただし、ニューラルネットワークNNは異なる単位の数値を入力として、やはりそれら入力とは単位の異なる路面摩擦係数 $\mu$ を演算するものであるから、入力値は無次元化(0.0~1.0の範囲内で正規化)する必要があり、出力値は無次元化された値として得られる。

【0031】表1は、図3に示すニューラルネットワークNNによって演算された路面摩擦係数 $\mu$ の結果を種々の車速 $v$ 毎に示しており、同時に路面摩擦係数 $\mu$ の真の値も示している。なお、この結果を得たニューラルネットワークNNは、3つの路面摩擦係数 $\mu$ (=1.0, 0.4, 0.1)に対して学習を行ったものである。

【0032】

【表1】

車速 $v$ (km/h)	路面摩擦係数 $\mu$ の演算値	路面摩擦係数 $\mu$ の真値
20	0.991180	0.90
	0.264537	0.25
40	0.983843	0.90
	0.188530	0.25
60	0.988882	0.90
	0.179086	0.25
80	0.993198	0.90
	0.168374	0.25
100	0.994919	0.90
	0.177218	0.25
120	0.995648	0.90
	0.178346	0.25
140	0.995988	0.90
	0.180522	0.25
160	0.996206	0.90
	0.182608	0.25

【0033】表1に示す結果からも判るように、ニューラルネットワークNNを用いることにより、直接測定することが非常に困難な路面摩擦係数 $\mu$ を、ある程度の精度で推定することが可能となるのである。なお、上記表1に示す結果を得たニューラルネットワークNNは、剛

体マスバネモデルを用いた車両の応答を使って学習を行っているため、その推定精度がやや低いかも知れないが、これは、実際に対象とする車両を種々の速度で且つ異なる摩擦係数の道路を走行させて運動特性を表すパラメータ(ここでは、操舵角 $\theta$ 、ヨーレート $\phi$ 、横滑り角

$\beta$ )を記録し、その記録したパラメータに基づいてニューラルネットワークNNの学習を行えば、より高い精度の推定が可能となる。また、ここでは3つの路面摩擦係数 $\mu$  ( $=1.0, 0.4, 0.1$ )に対して学習を行っているが、教師信号の種類をさらに多くすれば、ニューラルネットワークNNの推定精度をさらに上げることは可能である。

【0034】そして、コントローラ10内のマイクロコンピュータは、その推定された路面摩擦係数 $\mu$ を考慮して目標後輪舵角 $\delta_r^*$ を演算し、そして、実後輪舵角 $\delta_r$ がその目標後輪舵角 $\delta_r^*$ に一致するようにモータドライバ15に対して制御信号CSを出力する。つまり、本実施例にあっては、直接測定することが実質的に不可能な路面摩擦係数 $\mu$ を、測定が容易な操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 及び横滑り角 $\beta$ に基づいて推定することが可能であり、そして、その推定された路面摩擦係数 $\mu$ を用いて4WS車両の後輪舵角制御を行う構成となっているため、路面摩擦係数 $\mu$ を考慮せずに後輪舵角制御を行っていた従来の4WS車両よりもさらに操縦安定性が向上するようになるのである。

【0035】図5は、乾いた路面を車速 $v=120\text{ km/h}$ で直進走行中に、操舵角 $\theta$ を30度だけステップ状に変化させた場合のヨーレート $\phi$ 、横方向速度 $v_y$ 及び後輪舵角 $\delta_r$ の変化を示す波形図であって、波形Aは路面摩擦係数 $\mu$ を考慮しない従来の4WS車両の応答、波形Bは通常の2WS車両の応答を示している。このように、路面摩擦係数 $\mu$ を考慮せずに後輪を操舵する従来の4WS車両であっても、通常の2WS車両に比べて、ヨーレート $\phi$ のハンチングを抑制でき、横滑り角( $=v_y/v$ )も零に近づくため、運転し易くなっているといえる。

【0036】図6は、積雪のある路面を車速 $v=120\text{ km/h}$ で直進走行中に、操舵角 $\theta$ を30度だけステップ状に変化させた場合のヨーレート $\phi$ 、横方向速度 $v_y$ 及び後輪舵角 $\delta_r$ の変化を示す波形図であって、波形Aは路面摩擦係数 $\mu$ を考慮しない従来の4WS車両の応答、波形Bは通常の2WS車両の応答、波形Cは超音波センサ等により路面摩擦係数 $\mu$ を検出しその検出値に基づいて後輪操舵制御を行った4WS車両の応答、波形Dは本実施例の4WS車両の応答を示している。

【0037】これによれば、積雪のある路面では、従来の4WS車両でも横滑り角をそれほど抑えることができないのに対し、路面摩擦係数 $\mu$ を考慮して後輪操舵制御を行う4WS車両では、横滑り角を小さく抑えて運転が

し易くなっている。特に、本実施例の4WS車両であれば、積雪のある路面においても、従来の4WS車両が乾いた路面で達成できるのと同程度に横滑り角を小さくすることができる。つまり、本実施例の構成であれば、路面摩擦係数 $\mu$ の変化に関わらず、良好な操縦安定性を得ることができるのである。

【0038】ここで、本実施例にあっては、操舵角センサ21、車速センサ22、ヨーレートセンサ23及び横滑り角センサ24のそれぞれが車両走行状態検出手段に対応し、操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 及び横滑り角 $\beta$ のそれぞれが車両の走行状態に対応する。図7は本発明の第2実施例を示す図であり、この実施例は、統計的な数学モデルに基づくニューラルネットワークNNを用いた点に特徴がある。

【0039】具体的には、ニューラルネットワークNNは、出力層に3個のニューロン $n_r$ を設けることにより、3個の出力 $O_1$ 、 $O_2$ 及び $O_3$ を並列に出力するようになっている。そして、このニューラルネットワークNNも、上記第1実施例の場合と同様に車両に搭載される前に適宜学習を行っておく必要があるが、ニューラルネットワークNNの出力が $O_1$ 、 $O_2$ 、 $O_3$ という3つの数値として得られるため、これに対応した学習を行う必要がある。

【0040】ここでは、図7にも示すように、ニューラルネットワークNNの出力に対応した3つの教師信号 $T_1$ 、 $T_2$ 、 $T_3$ を用いるとともに、それら一つ一つを、既知の路面摩擦係数 $\mu_1^*$  ( $=1.0$ )、 $\mu_2^*$  ( $=0.4$ )、 $\mu_3^*$  ( $=0.1$ )に対応させ、そして、各教師信号 $T_1$ 、 $T_2$ 、 $T_3$ は、ニューラルネットワークNNの出力の個数に対応した3つの要素 $t_{.1}$ 、 $t_{.2}$ 、 $t_{.3}$  ( $\cdot=1, 2$ 又は $3$ )から構成している。この実施例では、 $T_1=(1, 0, 0)$   
 $T_2=(0, 1, 0)$   
 $T_3=(0, 0, 1)$

であり、それら各教師信号 $T_1$ 、 $T_2$ 、 $T_3$ の各要素 $t_{.1}$ 、 $t_{.2}$ 、 $t_{.3}$ と、出力 $O_1$ 、 $O_2$ 、 $O_3$ との誤差が小さくなるように、バックプロパゲーション等の学習アルゴリズムを利用して学習を行うのである。

【0041】表2は、表1と同様に図7に示すニューラルネットワークNNによって演算された路面摩擦係数 $\mu$ の結果を種々の車速 $v$ 毎に示した表である。

【0042】

【表2】



車速 v (km/h)	路面摩擦係数 $\mu$ の演算値	路面摩擦係数 $\mu$ の真値
20	0.992689	0.90
	0.388858	0.25
40	0.989257	0.90
	0.265836	0.25
60	0.991395	0.90
	0.233186	0.25
80	0.993508	0.90
	0.198746	0.25
100	0.993825	0.90
	0.240733	0.25
120	0.993211	0.90
	0.252868	0.25
140	0.991739	0.90
	0.268660	0.25
160	0.989257	0.90
	0.282755	0.25

【0043】ただし、ニューラルネットワークNNの出力が $O_1 \sim O_3$ の3つの数値であり、学習の際に上述したような教師信号 $T_1 \sim T_3$ を用いていることから、路

面摩擦係数 $\mu$ は、下記の(5)式に基づいて演算される。

$$\mu = \frac{\sum_{i=1}^3 (O_i \times \mu_i)}{\sum_{i=1}^3 O_i} \quad \dots (5)$$

表1及び表2を比較すると、本実施例のように統計的な数学モデルに基づくニューラルネットワークNNを用いた方が高精度に路面摩擦係数 $\mu$ を推定することができるのが判る。これは、一つの路面摩擦係数 $\mu$ を3つの出力 $O_1 \sim O_3$ で表現されるように、出力層に3つのニューロンnrを設けたため、推定精度に影響を与える重み係数の個数が増えるとともにニューロンnr間の結合関係が複雑になったことが主な原因である。

【0044】つまり、本実施例にあっては、直接測定することが実質的に不可能な路面摩擦係数 $\mu$ を、上記第1実施例よりもさらに高精度に推定することが可能であるから、その推定された路面摩擦係数 $\mu$ を用いて4WS車両の後輪舵角制御を行えば、上記第1実施例よりもさらに操縦安定性が向上するようになる。その他の作用効果等は上記第1実施例と同様であるためその説明は省略する。

【0045】なお、本実施例では、ニューラルネットワークNNの出力を3つとしているが、この個数は任意であり、マイクロコンピュータの演算能力等に応じて適宜増減できるものである。そして、ニューラルネットワークNNの出力の個数は多いほど高精度に路面摩擦係数 $\mu$ が推定されるようになるから、マイクロコンピュータの演算能力の範囲で可能な限り出力の個数は多くした方がよい。

【0046】図8及び図9は本発明の第3実施例を示す図であり、この実施例は、自己回帰モデルの一つであるARMA (Auto Regressive Moving Average) モデルを有するニューラルネットワークNNを用いた点に特徴がある。ここで、上記第1実施例で説明した図4にも示されるように、路面摩擦係数 $\mu$ が異なればヨーレート $\phi$ 及び横滑り角 $\beta$ の応答に特徴が現れるのであるが、操舵状態が変化した直後は、ヨーレート $\phi$ 及び横滑り角 $\beta$ は過

渡応答の状態であり、その過渡応答は路面摩擦係数 $\mu$ によっても異なるが1～4秒程度続いてしまうため、操舵状況が変化した後、ヨーレート $\phi$ 及び横滑り角 $\beta$ の応答が定常応答となるまでの間は路面摩擦係数 $\mu$ の推定精度が極端に落ちてしまう恐れがある。

【0047】つまり、高速道路を走行している場合のように同じ操舵状態が比較的長く続く走行状況であれば特に問題はないのであるが、通常の街中を走行している場合のように操舵状態が頻繁に変化する状況においては、路面摩擦係数 $\mu$ の推定精度が低い恐れがあることから、路面摩擦係数 $\mu$ を推定してもそれを後輪操舵制御等に有効に活用できないことになる。

【0048】これに対し、本実施例では、図7に示すように、入力 $l_1(t), \dots, l_n(t)$ （これら入力

は、例えば上記第1、第2実施例のように、操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 及び横滑り角 $\beta$ であってもよいし、後に説明する他の実施例のようにその他のセンサ出

$$y(t+1) = \sum_{i=1}^n \alpha_i(t) x(t-1) + \sum_{j=1}^l \beta_j(t) y(t-j)$$

$$+ \sum_{k=1}^m \gamma_k(t) z(t-k)$$

..... (6)

そして、ARMAモデル30の出力 $y(t+1)$ と、次の処理におけるARMAモデル30への入力 $x(t+1)$ との誤差 $e(t+1) = x(t+1) - y(t+1)$ が小さくなるように、最小自乗法を利用して、重み係数を $\alpha_i(t), \beta_j(t), \gamma_k(t)$ 及び記憶数を $n, l, m$ を適宜更新する処理を上記第1実施例で説明した図2に示す処理とともに実行する。

【0051】つまり、本実施例では、上記第1、第2実施例のように現在の入力値のみではなく、過去の入力や出力をそれに応じた重み係数を乗じてニューラルネットワークNNに取り込むとともに、ARMAモデル30の出力を利用してニューラルネットワークNNの一部をなすARMAモデル30内の重み係数や記憶数を更新する機能（即ち、オンライン学習機能）を備えているため、定常応答時だけでなく、操舵状態が変化し直後のように過渡応答時であっても、高精度に路面摩擦係数 $\mu$ を推定することができるのである。

【0052】よって、通常の街中を走行するような場合であっても、路面摩擦係数 $\mu$ を取り入れて後輪操舵制御を行うことができるから、全体的に操縦安定性を向上させることができるようになる。ちなみに、本実施例のように自己回帰モデルを有するニューラルネットワークNNを用いずに同等の効果をしようとすると、センサ入力を多数の周波数成分毎に分解し、各周波数成分毎に設けられたニューラルネットワークで演算を行い、それら各ニューラルネットワークの出力を時間軸上に戻して路面

力であってもよい。）とともにその時間遅れ値 $l_1(t-1), \dots, l_1(t-k), \dots, l_n(t-1), \dots, l_n(t-k)$ をニューラルネットワークNNの入力層に供給し、さらに、ニューラルネットワークNNの出力 $O_1(t), \dots, O_n(t)$ を時間遅れ演算部31及びARMAモデル30を介してニューラルネットワークNNの入力層に戻している。

【0049】ARMAモデル30の基本的概念の一例を図9に示す。この図9の例は、一つの主記憶30aと二つの補助記憶30b、30cとから構成されたものであって、その入力 $x(k)$ 及び出力 $y(k+1)$ 間の関係は、ARMAモデル内の重み係数を $\alpha_i(t), \beta_j(t), \gamma_k(t)$ 、主記憶30a及び補助記憶30b、30cの記憶数を $n, l, m$ とすれば、下記の(6)式のようなになる。

【0050】

摩擦係数 $\mu$ を演算する構成としなければならないが、十分な精度を得るためにはセンサ入力を非常に多く次数成分毎（例えば、100次以上）に分解する必要があるため、実質的に実現不可能である。

【0053】ここで、本実施例では、上述した最小自乗法を利用して重み係数及び記憶数を更新する処理によって、オンライン学習手段が構成される。なお、本実施例では、自己回帰モデルとしてARMAモデルを適用した場合について説明したが、他の自己回帰モデル、例えば、ARMAX（ARMA+ARX（Auto Regressive Exogenous））モデルや、拡張カルマンフィルタ等を用いてもよい。

【0054】図10は本発明の第4実施例を示す図であり、この実施例では、ニューラルネットワークNNへの入力として、操舵角 $\theta$ 、車速 $v$ 及びヨーレート $\phi$ の3つのセンサ出力を利用したものである。即ち、上記第1～第3実施例では、操舵角 $\theta$ 、車速 $v$ 、ヨーレート $\phi$ 及び横滑り角 $\beta$ の4つをニューラルネットワークNNへの入力としているのに対し、本実施例では、横滑り角 $\beta$ を省略しているのであり、横滑り角センサが不要である分、安価な構成とすることができる。つまり、横滑り角センサを有しない車両であっても、容易に適用することができるという利点がある。また、本実施例の構成は、特に4WS車両であれば既に必要なセンサが備えられていることから、安価に実現できる。

【0055】図11は本発明の第5実施例を示す図であ

り、上記第 4 実施例の構成に前後加速度  $Xg$  をニューラルネットワーク NN への入力として加えたものである。即ち、車体に発生するヨーレート  $\phi$  は、路面摩擦係数  $\mu$  の影響を受けて大きく変化するものであるが、その他に制動力の影響を受けても大きく変化するものであることから、その制動力に応じて変化する前後方向加速度  $Xg$  をニューラルネットワーク NN への入力とすることにより、路面摩擦係数  $\mu$  の推定精度を向上させようというものである。

【0056】例えば、路面摩擦係数  $\mu$  が 1.0 に近い乾いた路面を走行中に、軽いブレーキ操作をしつつステアリングを操舵すると、大きめのヨーレートが発生するが、同じ状況で強いブレーキ操作をすれば小さめのヨーレートが発生するのである。従って、本実施例のように前後方向加速度  $Xg$  をもニューラルネットワーク NN への入力とすれば、さらに高精度に路面摩擦係数  $\mu$  を推定することができるようになる。また、本実施例の構成は、特に 4WS 車両であれば必要なセンサが既に備えられていることから、安価に実現できる。

【0057】図 12 は本発明の第 6 実施例を示す図であり、上記第 5 実施例の構成に実後輪舵角  $\delta_r$  をニューラルネットワーク NN への入力として加えたものである。即ち、4WS 車両であれば、後輪舵角によっても発生するヨーレートが変化することから、実後輪舵角  $\delta_r$  をもニューラルネットワーク NN への入力とすればまたさらに高精度に路面摩擦係数  $\mu$  を推定することができるようになる。

【0058】図 13 は本発明の第 7 実施例を示す図であり、車輪回転数  $\omega$ 、ブレーキ圧力  $P$  及びブレーキトルク  $T_B$  をニューラルネットワーク NN への入力としたものである。即ち、路面摩擦係数  $\mu$  が異なれば、同じブレーキ圧力  $P$  に対する車輪回転数  $\omega$  及びブレーキトルク  $T_B$  が異なることから、本実施例の構成であっても、路面摩擦係数  $\mu$  の推定が可能となるのである。

【0059】特に、本実施例の構成であれば、車両の直進時であってもブレーキ操作が行われれば路面摩擦係数  $\mu$  を推定することができるという利点がある。また、本実施例の構成は、ABS を有する車両であれば必要なセンサは既に備えられていることから、安価に実現できる。図 14 は本発明の第 8 実施例を示す図であり、車輪回転数  $\omega$ 、エンジン回転数  $N_E$ 、スロットル開度  $\kappa$  及び駆動トルク  $T_E$  をニューラルネットワーク NN への入力としたものである。

【0060】このような構成であれば、アクセルを踏み込んだ時の車輪回転数  $\omega$  の変化から路面摩擦係数  $\mu$  を推定することができるから、直進走行時に単に加速する場合でも路面摩擦係数  $\mu$  を推定することができるようになる。また、本実施例の構成は、TCS を有する車両であれば必要なセンサは既に備えられていることから、安価に実現できる。

【0061】図 15 は本発明の第 9 実施例を示す図であり、操舵角  $\theta$  及びパワーステアリング装置の油圧  $P_s$  をニューラルネットワーク NN への入力としたものである。即ち、油圧式パワーステアリング装置を有する車両においては、路面摩擦係数  $\mu$  が異なれば、操舵角  $\theta$  に対して発生するパワステ油圧  $P_s$  が異なることから、本実施例の構成であっても、路面摩擦係数  $\mu$  の推定が可能となる。

【0062】そして、本実施例の構成であれば、4WS, ABS, TCS 等の特殊な機能を有しない車両であっても、安価に実現できるという利点がある。図 16 は本発明の第 10 実施例を示す図であり、上記第 9 実施例の構成に車速  $v$  をニューラルネットワーク NN への入力として加えたものである。このような構成であれば、上記第 9 実施例と同様の利点があり、車速感応型の油圧式パワーステアリング装置であっても高精度に路面摩擦係数  $\mu$  を推定することができるようになる。

【0063】図 17 は本発明の第 11 実施例を示す図であり、これは、上記各実施例で説明したような特徴を有するニューラルネットワーク NN を複数設けるとともに、それらニューラルネットワーク NN の出力である路面摩擦係数  $\mu$  をさらに別のニューラルネットワーク NN の入力とし、そのニューラルネットワーク NN でさらに路面摩擦係数  $\mu_0$  を演算しようとするものである。

【0064】このような構成であれば、上記各実施例で求められた路面摩擦係数  $\mu$  に基づいて路面摩擦係数  $\mu_0$  が求められることから、推定精度が飛躍的に向上するようになる。図 18 は本発明の第 12 実施例を示す図であり、この実施例は、上記第 4～第 11 実施例の機能を統合したものである。

【0065】即ち、上記第 4～第 11 実施例に必要なセンサ出力を全て読み込み可能とし、それらセンサ出力を、データローダ 35 及びスイッチ 36 を介して、必要な組み合わせにしてニューラルネットワーク NN に供給可能としたものである。そして、例えば車両が 4WS 車両として機能しており且つ操舵が行われている場合には上記第 4、第 5 又は第 6 実施例として機能させるべくそれに必要なセンサ出力をニューラルネットワーク NN に供給し、例えば制動時には上記第 7 実施例として機能させるべくそれに必要なセンサ出力をニューラルネットワーク NN に供給し、例えば加速時には上記第 8 実施例として機能させるべくそれに必要なセンサ出力をニューラルネットワーク NN に供給し、特に高精度の路面摩擦係数  $\mu$  の推定が必要な場合には上記第 11 実施例として機能させるべく全てのセンサ出力をニューラルネットワーク NN に供給する。なお、本実施例の場合、ニューラルネットワーク NN の入力数は選択された機能によって異なることになるが、非供給状態の入力層には“0”を入力するようにし、それに対応して適宜学習を行っておけばよい。

【0066】このような構成であれば、上記各実施例のそれぞれの利点を生かすことができるから、どのような状況においても路面摩擦係数 $\mu$ を推定し、これを各種制御に有効に用いることができるようになる。なお、上記各実施例では、特に4WS車両に本発明を適用した場合について説明したが、本発明を適用できる車両はこれに限定されるものではなく、4WD、ABS、TCS等の各種の機能を備えた車両であってもよいし、或いはエンジン制御やパワーステアリング制御等に適用することも可能である。

【0067】また、ニューラルネットワークNNへの入力としての車両の走行状態は、上記各実施例で説明したものに限定されるものではなく、要は、路面摩擦係数の影響を受けて変化し且つ検出が可能なものであれば何でもよい。

【0068】

【発明の効果】以上説明したように、本発明によれば、車両の走行状態を検出し、これをニューラルネットワークへの入力として路面摩擦係数を演算する構成としたため、直接検出可能なパラメータに基づき、直接測定が困難な路面摩擦係数を高精度に推定することができるという効果がある。


【0069】特に、請求項2記載の発明であれば、より高精度に路面摩擦係数を推定することができるという効果がある。さらに、請求項3記載の発明であれば、過渡応答時であっても高精度に路面摩擦係数を推定することができるという効果がある。

【図面の簡単な説明】

【図1】本発明の第1実施例における車両の構成を示す概念図である。

【図2】コントローラ内で実行される処理の概要を示す

【図1】



フローチャートである。

【図3】第1実施例におけるニューラルネットワークの構成を示す概念図である。

【図4】操舵に対するヨーレート及び横滑り角の応答の例を示す波形図である。

【図5】従来の4WS車両の制御効果を説明する波形図である。

【図6】本実施例の効果を説明する波形図である。

【図7】第2実施例におけるニューラルネットワークの構成を示す概念図である。

【図8】第3実施例におけるニューラルネットワークの構成を示す概念図である。

【図9】ARMAモデルの一例を示す概念図である。

【図10】第4実施例の構成図である。

【図11】第5実施例の構成図である。

【図12】第6実施例の構成図である。

【図13】第7実施例の構成図である。

【図14】第8実施例の構成図である。

【図15】第9実施例の構成図である。

【図16】第10実施例の構成図である。


【図17】第11実施例の構成図である。

【図18】第12実施例の構成図である。

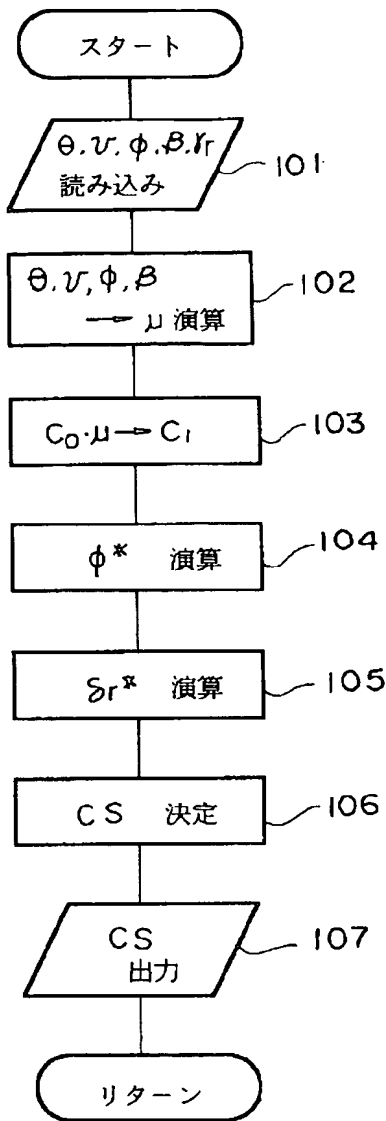
【符号の説明】

20	コントローラ
21	操舵角センサ
22	車速センサ
23	ヨーレートセンサ
24	横滑り角センサ
25	後輪舵角センサ
NN	ニューラルネットワーク

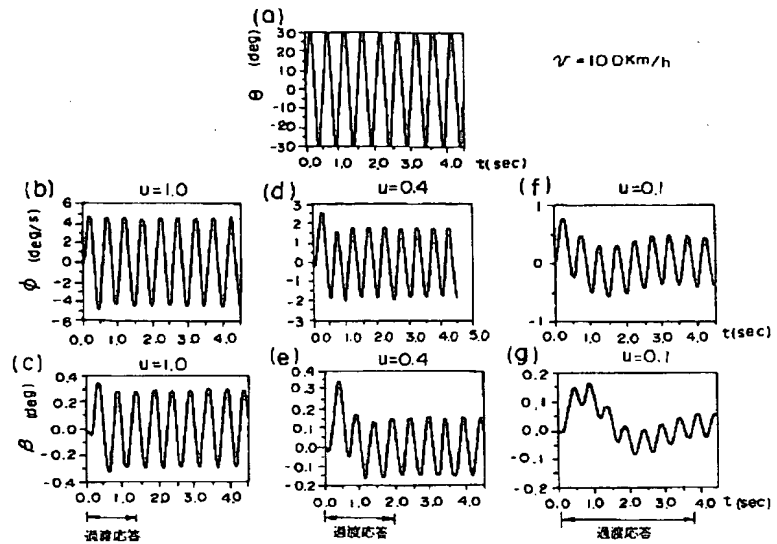
【図3】




【図2】




【図4】




【図5】




【図6】




【図11】




【図12】




【図7】




【図9】




【図8】




【図14】




【図15】




【図10】



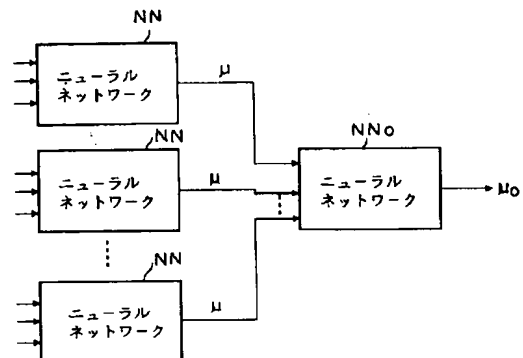
【図13】




【図 16】



【図 17】



【図 18】



フロントページの続き

(51) Int. Cl. 5

識別記号

庁内整理番号

F I

技術表示箇所

B 6 2 D 113:00

123:00

127:00

137:00